PATENT ABSTRACTS OF JAPAN

(11)Publication number : 2002-230021
(43)Date of publication of application : 16.08.2002

(51)Int.Cl. G06F 17/30

(21)Application number : 2001-021796
(22)Date of filing : 30.01.2001

(71)Applicant : CANON INC
(72)Inventor : TOSHIMA EIICHIRO

(54) INFORMATION RETRIEVAL DEVICE AND METHOD, AND STORAGE MEDIUM

(57)Abstract:
PROBLEM TO BE SOLVED: To easily and quickly perform information retrieval intended by a user.
SOLUTION: A word is extracted from a retrieval query designated by a user, and modification analysis is operated (S41), and polysemy elimination is tried based on the result of the modification analysis and a co-occurrence data base (S42), and when the polysemy is eliminated, the processing is immediately moved to a S45, and in the other case, polysemy elimination based on user profile information is operated, and then the processing is moved to the S45. Then, extension processing such as near-synonym development is operated by using a query extension dictionary (S45), and the document vector generation processing of the retrieval query is operated (S46).

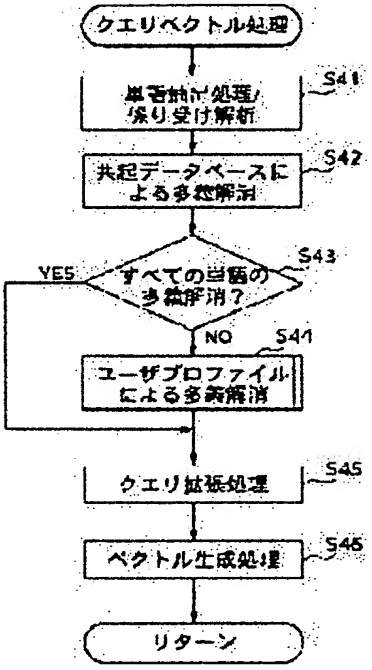

LEGAL STATUS

[Date of request for examination]

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of rejection]

[Date of requesting appeal against

(19)日本国特許庁（ＪＰ）　(12)公開特許公報（Ａ）　(11)特許出願公開番号
特開2002－230021
（P2002－230021A）
(43)公開日　平成14年８月16日(2002.8.16)

(51)Int.Cl.⁷	識別記号	ＦＩ	ﾃｰﾏｺｰﾄﾞ(参考)
Ｇ０６Ｆ　17/30	３３０	Ｇ０６Ｆ　17/30	３３０Ｃ　５Ｂ０７５
	１７０		１７０Ａ
	３２０		３２０Ｄ
	３４０		３４０Ａ
	３５０		３５０Ｃ

審査請求　未請求　請求項の数27　ＯＬ　（全 14 頁）

(21)出願番号　特願2001－21796(P2001－21796)

(22)出願日　平成13年１月30日(2001.1.30)

(71)出願人　000001007
キヤノン株式会社
東京都大田区下丸子３丁目30番２号
(72)発明者　戸島　英一朗
東京都大田区下丸子３丁目30番２号　キヤノン株式会社内
(74)代理人　100081880
弁理士　渡部　敏彦

Ｆターム(参考)　5B075 ND03 NK35 PP24 PQ02 PQ36 PR06 PR08 QM08 QP03

(54)【発明の名称】　情報検索装置及び情報検索方法並びに記憶媒体

(57)【要約】
【課題】　ユーザの意図に即した情報検索を容易且つ迅速に行うことのできるようにした。
【解決手段】　ユーザ指定の検索クエリから単語を抽出し、係り受け解析を行った後（Ｓ４１）、係り受け解析の結果と共起データベースとに基づいて多義解消を試み（Ｓ４２）、多義性が解消された場合は直ちにＳ４５に進む一方、解消されなかった場合はユーザプロファイル情報に基づく多義解消を行い、その後、Ｓ４５に進む。そして、クエリ拡張辞書を使用し類義語展開等の拡張処理を行った後（Ｓ４５）、検索クエリの文書ベクトル生成処理を行う（Ｓ４６）。

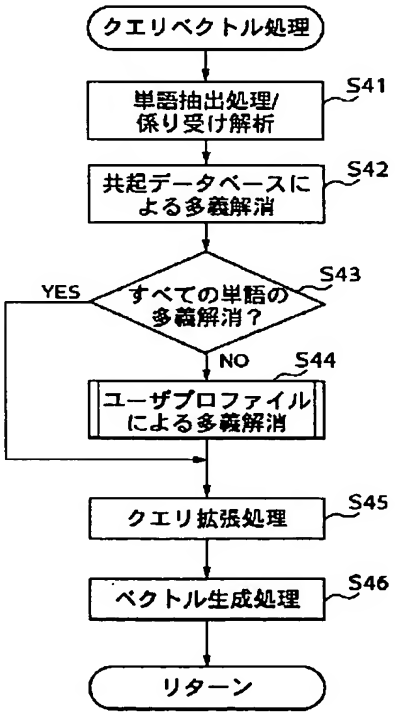

【特許請求の範囲】

【請求項１】　検索条件を入力する検索条件入力手段と、該検索条件入力手段により入力された検索条件から単語を抽出する形態素解析手段と、複数の単語間の共起関係を語義と関連付けて記憶する共起関係記憶手段と、該共起関係記憶手段に記憶された共起情報と前記形態素解析手段の解析結果とに基づいて前記検索条件の共起関係を抽出し多義性を解消する第１の多義性解消手段と、該第１の多義性解消手段により多義性の解消された語義に基づいて情報検索を行う情報検索手段とを有することを特徴とする情報検索装置。

【請求項２】　前記第１の多義性解消手段により多義性の解消された語義に対し拡張処理を行う語義拡張手段を備えていることを特徴とする請求項１記載の情報検索装置。

【請求項３】　前記語義拡張手段は、少なくとも語義を類義語展開する類義語展開手段と、関連語に展開する関連語展開手段と、これらを組み合わせた組み合わせ展開手段とを含んでいることを特徴とする請求項２記載の情報検索装置。

【請求項４】　ユーザの嗜好を表現するユーザプロファイル情報が記憶されたユーザプロファイル記憶手段と、前記ユーザプロファイル記憶手段に記憶されたユーザプロファイル情報と前記形態素解析手段の解析結果とに基づいて前記検索条件の多義性を解消する第２の多義性解消手段とを備え、前記第１の多義性解消手段は前記第２の多義性解消手段より優先することを特徴とする請求項１乃至請求項３のいずれかに記載の情報検索装置。

【請求項５】　前記第２の多義性解消手段により多義性の解消された語義に対し拡張処理を行う語義拡張手段を備えていることを特徴とする請求項４記載の情報検索装置。

【請求項６】　前記語義拡張手段は、少なくとも語義を類義語展開する類義語展開手段と、関連語に展開する関連語展開手段と、これらを組み合わせた組み合わせ展開手段とを含んでいることを特徴とする請求項５記載の情報検索装置。

【請求項７】　前記第１の多義性解消手段により多義性の解消された語義に基づいて文書ベクトルを生成する文書ベクトル生成手段と、該文書ベクトル生成手段により生成された文書ベクトルをデータベースとして登録する登録手段とを有していることを特徴とする請求項１乃至請求項６のいずれかに記載の情報検索装置。

【請求項８】　前記第１の多義性解消手段により多義性の解消された語義に基づいて文書ベクトルを生成する文書ベクトル生成手段と、ユーザの嗜好を表現するユーザプロファイル情報が記憶されたユーザプロファイル記憶手段の記憶内容を前記文書ベクトル生成手段により生成された文書ベクトルに基づいて更新するユーザプロファイル情報更新手段とを有していることを特徴とする請求項１乃至請求項７のいずれかに記載の情報検索装置。

【請求項９】検索条件を入力する検索条件入力手段と、該検索条件入力手段により入力された検索条件から単語を抽出する形態素解析手段と、ユーザの嗜好を表現するユーザプロファイル情報が記憶されたユーザプロファイル記憶手段と、該ユーザプロファイル情報と前記形態素解析手段の解析結果とに基づいて前記検索条件の多義性を解消する第２の多義性解消手段と、該第２の多義性解消手段により多義性の解消された語義に基づいて情報検索を行う情報検索手段とを有することを特徴とする情報検索装置。

【請求項１０】　検索条件を入力する検索条件入力ステップと、該検索条件入力ステップで入力された検索条件から単語を抽出する形態素解析ステップと、複数の単語間の共起関係を語義と関連付けて記憶された共起情報と前記形態素解析ステップでの解析結果とに基づいて前記検索条件の共起関係を抽出し多義性を解消する第１の多義性解消ステップと、該第１の多義性解消ステップで多義性の解消された語義に基づいて情報検索を行う情報検索ステップとを含むことを特徴とする情報検索方法。

【請求項１１】　前記第１の多義性解消ステップで多義性の解消された語義に対し拡張処理を行う語義拡張ステップを含んでいることを特徴とする請求項１０記載の情報検索方法。

【請求項１２】　前記語義拡張ステップは、少なくとも語義を類義語展開する類義語展開ステップと、関連語に展開する関連語展開ステップと、これらを組み合わせた組み合わせ展開ステップとを含んでいることを特徴とする請求項１１記載の情報検索方法。

【請求項１３】　ユーザの嗜好を表現するユーザプロファイル情報と前記形態素解析ステップの解析結果とに基づいて前記検索条件の多義性を解消する第２の多義性解消ステップを備え、前記第１の多義性解消ステップは前記第２の多義性解消ステップより優先することを特徴とする請求項１０乃至請求項１２のいずれかに記載の情報検索方法。

【請求項１４】　前記第２の多義性解消ステップで多義性の解消された語義に対し拡張処理を行う語義拡張ステップを含んでいることを特徴とする請求項１３記載の情報検索方法。

【請求項１５】　前記語義拡張ステップは、少なくとも語義を類義語展開する類義語展開ステップと、関連語に展開する関連語展開ステップと、これらを組み合わせた組み合わせ展開ステップとを含んでいることを特徴とする請求項１４記載の情報検索装置。

【請求項１６】　前記第１の多義性解消ステップで多義性の解消された語義に基づいて文書ベクトルを生成する文書ベクトル生成ステップと、該生成された文書ベクトルをデータベースとして登録手段に登録する登録ステップとを含んでいることを特徴とする請求項１０乃至請求

項１５のいずれかに記載の情報検索方法。

【請求項１７】　前記第１の多義性解消ステップで多義性の解消された語義に基づいて文書ベクトルを生成する文書ベクトル生成ステップと、ユーザの嗜好を表現するユーザプロファイル情報が記憶されたユーザプロファイル記憶手段の記憶内容を前記生成された文書ベクトルに基づいて更新するユーザプロファイル情報更新ステップとを含んでいることを特徴とする請求項１０乃至請求項１６のいずれかに記載の情報検索方法。

【請求項１８】　検索条件を入力する検索条件入力ステップと、該検索条件入力手段により入力された検索条件から単語を抽出する形態素解析ステップと、ユーザの嗜好を表現するユーザプロファイル情報が記憶されたユーザプロファイル情報と前記形態素解析ステップの解析結果とに基づいて前記検索条件の多義性を解消する第２の多義性解消ステップと、該第２の多義性解消ステップにより多義性の解消された語義に基づいて情報検索を行う情報検索ステップとを含むことを特徴とする情報検索方法。

【請求項１９】　入力装置から入力された検索条件に基づいて情報検索を行う情報検索手順が記憶されたコンピュータ読み取り可能な記憶媒体であって、
前記入力された検索条件から単語を抽出する形態素解析手順と、複数の単語間の共起関係を語義と関連付けて記憶された共起情報と前記形態素解析手順の解析結果とに基づいて前記検索条件の共起関係を抽出し多義性を解消する第１の多義性解消手順と、該第１の多義性解消手順により多義性の解消された語義に基づいて情報検索を行う情報検索手順とが記憶されていることを特徴とするコンピュータ読み取り可能な記憶媒体。

【請求項２０】　前記第１の多義性解消手順で多義性の解消された語義に対し拡張処理を行う語義拡張手順が記憶されていることを特徴とする請求項１９記載の記憶媒体。

【請求項２１】　前記第１の多義性解消手順より優先される、ユーザの嗜好を表現するユーザプロファイル情報と前記係り受け解析ステップの解析結果とに基づいて前記検索条件の多義性を解消する第２の多義性解消手順が記憶されていることを特徴とする請求項１９又は請求項２０記載の記憶媒体。

【請求項２２】　前記第２の多義性解消手順で多義性の解消された語義に対し拡張処理を行う語義拡張手順が記憶されていることを特徴とする請求項２１記載の記憶媒体。

【請求項２３】　前記第１の多義性解消手順で多義性の解消された語義に基づいて文書ベクトルを生成する文書ベクトル生成手順と、該生成された文書ベクトルをデータベースとして登録手段に登録する登録手順とが記憶されていることを特徴とする請求項１９乃至請求項２２のいずれかに記載の記憶媒体。

【請求項２４】　前記第１の多義性解消手順で多義性の解消された語義に基づいて文書ベクトルを生成する文書ベクトル生成手順と、ユーザの嗜好を表現するユーザプロファイル情報が記憶されたユーザプロファイル記憶手段の記憶内容を前記生成された文書ベクトルに基づいて更新するユーザプロファイル情報更新ステップとが記憶されていることを特徴とする請求項１９乃至請求項２３のいずれかに記載の記憶媒体。

【請求項２５】　語義ベースで単語の意味ベクトルが格納された単語ベクトル辞書と、検索対象となる文書データベースと、ユーザの嗜好を記録したユーザプロファイルと、係り受け単語間の共起関係が格納された共起データベースとからなるデータ構造を有していることを特徴とするコンピュータ読み取り可能な記憶媒体。

【請求項２６】　検索条件を拡張処理するための拡張辞書が格納されていることを特徴とする請求項２５記載の記憶媒体。

【請求項２７】　入力装置から入力された検索条件に基づいて情報検索を行う情報検索手順が記憶されたコンピュータ読み取り可能な記憶媒体であって、
前記入力された検索条件から単語を抽出する形態素解析手順と、ユーザの嗜好を表現するユーザプロファイル情報が記憶されたユーザプロファイル情報と前記形態素解析手順の解析結果とに基づいて前記検索条件の多義性を解消する第２の多義性解消手順と、該第２の多義性解消手順により多義性の解消された語義に基づいて情報検索を行う情報検索手順とが記憶されていることを特徴とするコンピュータ読み取り可能な記憶媒体。

【発明の詳細な説明】

【０００１】

【発明の属する技術分野】本発明は情報検索装置及び情報検索方法並びに記憶媒体に関し、より詳しくは、入力された検索文や検索キーワード等の検索条件（以下、「クエリ」という）に従って情報検索を行う情報検索装置、及び該情報検索装置を使用した情報検索方法、並びに情報検索の検索手順や情報検索を行うためのデータ構造が記憶された記憶媒体に関する。

【０００２】

【従来の技術】近年におけるコンピュータや通信網（ネットワーク）の発達に伴い、大量の電子化された文書のデータベースへの蓄積が進展してきており、それに伴って電子化された大量のデータベースから所望の文書データを検索する情報検索の需要が高まってきている。

【０００３】この種の情報検索は、従来、キーワード検索、全文検索のようなクエリとの表記の一致を前提とした検索方法が主流であったが、最近では特定のクエリや文書に類似している類似文書の検索を行う手法が提案されている。

【０００４】そして、このような類似文書の検索手法として、文書をｎ次元のベクトル空間上の点にマッピング

し、それらの間の距離の大小により文書同士の類似性、又はクエリと文書との類似性を算出するベクトル空間モデル方式が既に知られている（例えば、「熊本，島田，加藤：概念ベースの情報検索への適用，信学技報，Vol. AI98-63，pp. 9-16，1999」）。

【０００５】しかしながら、このようなベクトル空間モデル方式では、特に短い文章をクエリとして類似文書の検索を行った場合、ユーザの所望しない文書が検索されることも多い。

【０００６】すなわち、クエリに使用される文字列は多義性を有するため、前記クエリがユーザの所望する意味に解釈されなかったり、或いはクエリに使用される文字列の語義の解釈が不完全であるためにクエリの意味が十分に補完されず、このため、上述したベクトル空間モデル方式では検索結果がユーザの意図通りにならない場合が多い。

【０００７】そこで、斯かるユーザの意図しない文書の検索を極力回避する方策として、クエリを類義語で拡張する際に、単語間で共起性の低い類義語を展開対象から除外する技術が提案されている（例えば、特開平１１－４５２７４号公報；以下「第１の従来技術」という）。

【０００８】該第１の従来技術では、前記共起性の低い類義語を文書検索の検索対象から取り除くことにより、ユーザの所望する文書とは無関係な類義語の出現している文書を検索対象から除外している。

【０００９】また、その他の従来技術としては、各ユーザの文書ごとのアクセス状況を記録して該アクセス状況に基づいた嗜好ベクトルを作成し、クエリのベクトルを嗜好ベクトルに近付くようにシフトさせた技術も提案されている（特開平１１－５３３９４号公報；以下、「第２の従来技術」という）。

【００１０】該第２の従来技術では、クエリのベクトルを嗜好ベクトルに近づくようにシフトさせることにより、検索結果がユーザの嗜好に近付くようにし、これによりユーザの嗜好を反映した文書の検索を可能にしている。

【００１１】

【発明が解決しようとしている課題】しかしながら、上記第１の従来技術は、クエリの意味を拡張するために類義語展開する際に共起性の低い類義語を除外しているのみであるため、クエリ中の各単語の語義が特定されず、したがって各単語の多義性は依然として解消されず、ユーザの所望しない文書が検索結果として表示されることも多いという問題点があった。

【００１２】すなわち、第１の従来技術では、例えば、ユーザがクエリとして「フォームの種類にどんなものがあるか教えてくれ」という文字列を入力した場合、帳票に関するドキュメントや野球の投球フォームに関するドキュメントを含め多くのドキュメントが検索され、クエリが多義性を保持した状態で表示出力される。

【００１３】しかしながら、金融の帳票設計を業務とするユーザには、帳票の種類に関するドキュメントが必要であって野球の投球姿勢や水泳の泳法等に関するドキュメントは通常は必要としない。一方、スポーツを趣味とするユーザにとっては、野球の投球姿勢や水泳の泳法に関するドキュメントを所望する場合が多く、帳票の種類に関するドキュメントは通常は所望しない場合が多い。

【００１４】すなわち、上記第１の従来技術では、共起性の低い類義語は排除されるものの、クエリの有する多義性を保持した状態で検索されるため、ユーザの意図した文書以外に多数の文書が表示出力され、このため所望の検索結果を容易且つ迅速に得ることができないという問題点があった。

【００１５】また、第２の従来技術は、クエリ全体の意味をユーザの過去の嗜好、すなわち嗜好履歴の方向に強制的にシフトしているため、例えば、帳票の設計者が野球の投手の投球フォームを調べたいときには、システム上での語義解釈に誤解が生じないように、単なる「フォームの種類」ではなく、「投球フォームの種類」という文字列の入力を考慮する必要が生じ、このため使い勝手が悪くなるという問題点があった。

【００１６】しかも、該第２の従来技術では、クエリが一律に嗜好ベクトルに近付くため、たとえ、「投球フォームの種類」の文字列を入力した場合であっても、帳票の設計者に対しては帳票に関するドキュメントが検索される虞もあり、その結果ユーザの所望しない検索結果が表示される場合があるという問題点があった。

【００１７】このように上記第１及び第２の従来技術では、クエリの表記内容やユーザの嗜好に基づいて検索処理されているに過ぎず、クエリの有する多義性が考慮されず、またクエリの意味内容の補完も十分に行われていないため、ユーザの所望しない検索結果が得られることも多いという問題点があった。

【００１８】本発明はこのような問題点に鑑みなされたものであって、ユーザの意図に即した情報検索を容易且つ迅速に行うことのできる情報検索装置及び情報検索方法並びに記憶媒体を提供することを目的とする。

【００１９】

【課題を解決するための手段】上記目的を達成するために本発明に係る情報検索装置は、検索条件を入力する検索条件入力手段と、該検索条件入力手段により入力された検索条件から単語を抽出する形態素解析手段と、複数の単語間の共起関係を語義と関連付けて記憶する共起関係記憶手段と、該共起関係記憶手段に記憶された共起情報と前記形態素解析手段の解析結果とに基づいて前記検索条件の共起関係を抽出し多義性を解消する第１の多義性解消手段と、該第１の多義性解消手段により多義性の解消された語義に基づいて情報検索を行う情報検索手段とを有することを特徴とし、ユーザの嗜好を表現するユーザプロファイル情報が記憶されたユーザプロファイル

記憶手段と、前記ユーザプロファイル記憶手段に記憶されたユーザプロファイル情報と前記形態素解析手段の解析結果とに基づいて前記検索条件の多義性を解消する第２の多義性解消手段とを備え、前記第１の多義性解消手段は前記第２の多義性解消手段より優先することを特徴としている。

【００２０】また、本発明に係る情報検索方法は、検索条件を入力する検索条件入力ステップと、該検索条件入力ステップで入力された検索条件から単語を抽出する形態素解析ステップと、複数の単語間の共起関係を語義と関連付けて記憶された共起情報と前記形態素解析ステップでの解析結果とに基づいて前記検索条件の共起関係を抽出し多義性を解消する第１の多義性解消ステップと、該第１の多義性解消ステップで多義性の解消された語義に基づいて情報検索を行う情報検索ステップとを含むことを特徴とし、さらにユーザの嗜好を表現するユーザプロファイル情報と前記形態素解析ステップの解析結果とに基づいて前記検索条件の多義性を解消する第２の多義性解消ステップを備え、前記第１の多義性解消ステップは前記第２の多義性解消ステップより優先することを特徴としている。

【００２１】また、本発明に係る記憶媒体は、前記第１の多義性解消手順より優先される、ユーザの嗜好を表現するユーザプロファイル情報と前記係り受け解析ステップの解析結果とに基づいて前記検索条件の多義性を解消する第２の多義性解消手順が記憶されていることを特徴とし、さらに前記第２の多義性解消手順で多義性の解消された語義に対し拡張処理を行う語義拡張手順が記憶されていることを特徴ととしている。

【００２２】尚、本発明のその他の特徴は、下記の発明の実施の形態の記載より明らかとなろう。

【００２３】

【発明の実施の形態】次に、本発明の実施の形態を図面に基づいて詳説する。

【００２４】図１は本発明に係る情報検索装置としての文書検索装置の一実施の形態を示すブロック構成図であって、該文書検索装置は、キーボードやマウス等からなる入力装置１と、ＣＲＴや液晶ディスプレイ等からなる表示装置２と、後述する所定のデータが格納されたハードディスク（ＨＤ）３と、フレキシブルディスク（ＦＤ）やＣＤ（コンパクトディスク）、ＤＶＤ（デジタルビデオディスク）等の外部記憶媒体にアクセスするためのリムーバブルディスクドライブ４と、通信回線を介して外部とデータ交換を行うモデムやＬＡＮコントローラ等の通信装置５と、後述する所定の制御プログラムが格納された読出し専用の固定メモリ（ＲＯＭ）６と、各種データを一時的に記憶したりワークエリアとして使用される書込み可能なランダムアクセスメモリ（ＲＡＭ）７と、バス８を介して上記各構成要素に接続され装置全体を制御する中央演算処理装置（ＣＰＵ）９とを備えている。

【００２５】また、ＨＤ３には、語義ベースで単語の意味ベクトルが格納された単語ベクトル辞書３ａ、検索対象となる文書データベース３ｂ、ユーザの嗜好を記録したユーザプロファイル３ｃ、係り受け単語間の共起関係が格納された共起データベース３ｄ、及びクエリの類義語展開や関連展開を行うクエリ拡張辞書３ｅが格納されている。

【００２６】尚、本実施の形態では、ＣＰＵ９で演算処理される制御プログラムは、ＲＯＭ６に記憶されているが、該ＲＯＭ６に代えてＨＤ３に記憶させ、該HD３からＲＡＭ７上にロードして実行してもよく、或いはＦＤ等の外部記憶媒体に記憶させリムーバルディスクドライブ４を介してＲＡＭ７上にロードし実行するようにしてもよい。

【００２７】図２は表示装置２の表示画面の一例を示した図であって、該表示画面はクエリ（検索条件）を表示するクエリ表示部２ａと、クエリに基づいた検索結果を表示する検索結果表示部２ｂとから構成されている。

【００２８】クエリ表示部２ａは、具体的には、ユーザが入力装置１を介して入力した検索条件、例えば、自然文（「フォームの種類」「フォームの種類について知りたい」「投球フォームのバリエーション」等）、複数のキーワードの羅列（「フォーム、種類」等）、又はユーザの指示する既存文書（「文書番号２６７」等）が表示される。

【００２９】そして、検索結果表示部２ｂには、検索結果として各文書を識別する文書ＩＤ、及び文書ＩＤに対応した文書タイトル、及びクエリに対する文書ＩＤの類似度が表示される。

【００３０】図３はＨＤ３に格納される単語ベクトル辞書３ａのフォーマット図ある。

【００３１】単語ベクトル辞書３ａは、各単語の語義を示す意味ベクトル（意味分類ごとの特徴量リスト）の集合であって、各次元（１、２、３、…）は意味分類を表現している。

【００３２】すなわち、単語ベクトル辞書３ａでは、特定の語義が各単語（１、２、３、…）に意味付けられており、各単語に対して各次元の意味分類がどの程度含意されているか、つまり意味ベクトルの特徴量がマトリックス状に書き込まれている。

【００３３】例えば、次元３は「宇宙・空」という意味分類を示し、次元４は「取引・売買」という意味分類を示し、次元７は「身振り・動作」という意味分類を示し、一方、単語７は「フォーム（帳票）」という特定の語義に意味付けられている。そして、該単語ベクトル辞書３ａでは単語７における次元３の意味ベクトルの特徴量は「０」であるため、「フォーム(帳票)」という単語には「宇宙・空」の意味を全く有していないことが分かる。

【００３４】また、単語７では次元４の特徴量が「２１」と他の特徴量に比べて相対的に大きく、単語７における次元７の特徴量は「１」と相対的に小さいが、これは「フォーム（帳票）」が「取引・売買」という意味の寄与度は大きいが、「身振り・動作」という意味の寄与度は小さいことを示している。

【００３５】また、単語８は「フォーム（姿勢）」という語義を有しており、単語８においては次元４の特徴量は「０」であり、次元７の特徴量は「２３」と相対的に大きい。これは「フォーム（姿勢）」には「取引・売買」という意味が全く存在しないが、「身振り・動作」という意味の寄与度は大きいことを示している。

【００３６】このように単語ベクトル辞書３ａにより、語義別の各単語の意味する寄与度を認識することができる。

【００３７】図４はＨＤ３に格納された文書データベース３ｂのフォーマット図であって、該文書データベース３ｂには文書ベクトルの特徴量が書き込まれている。

【００３８】文書の意味は文書中でどのような単語が使用されたかによって決定されると判断し、各文書の意味は、その文書を構成する単語の意味ベクトルを加算していくことで算出される。したがって、算出されたベクトルの次元は単語ベクトル辞書３ａの意味ベクトルの次元と同一となり、特定の意味分類を表現する。そして、加算されて得られたベクトルは「１」を基準に正規化され、該正規化されたベクトルが文書ベクトルの特徴量として文書データベース３ｂに格納される。

【００３９】この図４から明らかなように、例えば、文書ＩＤが「６９４９」の場合では次元４の特徴量は「０．００９」であり、次元７の特徴量は「０．４２５」であり、文書ＩＤが「６９５３」の場合では次元４の特徴量は「０．３６２」、であり、次元７の特徴量は「０．００８」である。そしてこれにより文書ＩＤが「６９４９」の文章は、「身振り・手振り」の意味分類は或る程度含んでいるが、「取引・売買」の意味分類を殆ど含んでおらず、また、文書ＩＤが「６９５３」の文章は「取引・売買」の意味分類は或る程度含んでいるが、「身振り・動作」の意味分類をほとんど含んでいないことが分かる。

【００４０】図５はＨＤ３に格納されたユーザプロファイル３ｃのフォーマット図である。

【００４１】ユーザプロファイル３ｃも単語ベクトル辞書３ａの意味ベクトルと同一の次元を有し、ユーザがドキュメントファイルにアクセスする毎にプロファイルが更新される。

【００４２】すなわち、初期状態ではプロファイルは「０」に設定されているが、ユーザが特定のドキュメントにアクセスすると、当該ドキュメントの文書ベクトルが算出され、算出された値が累積プロファイルに加算される。そして、新たな累積プロファイルが得られた後、プロファイルは「１」を基準にして正規化され、正規化プロファイルの更新が行なわれる。

【００４３】図５（ａ）は、例えばスポーツに関心のあるユーザのプロファイルを示しており、次元７（身振り、動作）の特徴量が「０．１８６」と比較的大きくなっている。これは該ユーザが「身振り・動作」の意味分類を有するドキュメントを多く参照していることを示している。

【００４４】一方、図５（ｂ）は窓口業務に関心の深いユーザのプロファイルを示しており、次元７（身振り、動作）の特徴量は「０．０００」であるが、次元４（取引・売買）の特徴量は「０．３２９」と大きな数値を示している。これは該ユーザが「取引・売買」に関するドキュメントを多く参照していることを示している。

【００４５】図６はＨＤ３に格納される共起データベース３ｄのフォーマット図であり、係り単語、受け単語、及び両者間に介在する助詞の３つの共起情報が記憶されている。尚、前記助詞が存在しないときは「ｎｕｌｌ」が書き込まれる。

【００４６】本実施の形態では、入力されたクエリ中の文字列を形態素解析した後、係り受け解析を行って係り単語、受け単語、及び助詞情報を抽出し、共起データベース３ｄを参照し、これら係り単語、受け単語、及び助詞情報の間で照合処理を行う。そして、共起データベース３ｄに上記係り単語、受け単語、及び助詞情報に対応する文字列がある場合は、各単語は共起データベース３ｄに記載通りの語義であると解釈される。

【００４７】例えば、「投球フォーム」という語句が係り受け解析によって「投球／フォーム」と抽出されたときは、このフォームの語義は共起データベース３ｄに従って「姿勢」の語義と解釈される。また、クエリが「フォームに情報を入力する」という場合は、係り受け解析により「フォーム／に／入力」という単語及び助詞が抽出され、これら単語及び助詞と共起データベース３ｄとの間で照合処理がなされ、その結果、この「フォーム」は「帳票」の語義であると解釈される。

【００４８】図７はＨＤ３に格納されるクエリ拡張辞書３ｅのフォーマット図であって、図７（ａ）は類義語辞書、図７（ｂ）は関連語辞書を示している。

【００４９】すなわち、類義語辞書には見出語に対して展開されるべき類義語が格納されている。例えば、見出語「フォーム（姿勢）」には類義語として「姿勢、形、スタイル、ポーズ」が格納され、見出語「フォーム（帳票）」には類義語として「書式、伝票、帳票」が格納されている。

【００５０】尚、通常、類義語は見出語に対して同義概念または下位概念の関係にある。そして、類義語辞書はクエリ中の各単語を展開し、各単語の意味内容を許容範囲まで拡張するために使用される。従来はクエリ中に表記された「フォーム」に対し展開される類義語を有して

いたため、「姿勢」と「帳票」が混在されて展開されていたが、本実施の形態では、類義語辞書は語義ベースで保持されるので、「姿勢」と「帳票」が混在されて展開されることはない。尚、類義語にも語義情報が格納されており、類義語展開後も語義ベースで処理が可能である。

【００５１】また、関連語辞書は、起点語に対して展開されるべき関連語が格納されている。例えば、起点語「フォーム（姿勢）」には関連語としては「スポーツ、分析、改善」が格納され、起点語「フォーム（帳票）」には関連語としては「購入、申し込み、振込み、送金」が格納されている。

【００５２】尚、関連語は、上述した類義語とは異なり、起点語との間には上位下位の関係は存在しない。そして、関連語辞書はクエリ中の各単語を展開して、クエリ全体の意味内容をある程度充実させるために使用される。

【００５３】このように構成された文書検索装置は、入力装置１からの各種の入力に応じて作動し、該入力装置１からの入力信号がＣＰＵ９に供給され、該ＣＰＵ９がＲＯＭ６内に記憶してある制御プログラムを読み出し、該制御プログラムに従って、各種の制御が行われる。

【００５４】図８は本文書検索装置で実行される文書検索方法の処理手順の一実施の形態を示すフローチャートであって、本プログラムはＣＰＵ９で実行される。

【００５５】ステップＳ１で各種パラメータの初期化や初期画面の点灯等、初期化処理を行った後、ステップＳ２では入力装置１からの操作入力を待機し、続くステップＳ３では入力された操作内容を判別する。

【００５６】すなわち、本文書検索方法の検索手順は、文書データベースへの登録処理、ユーザプロファイルの更新処理、及びクエリに応じた検索実行処理の３つに大別され、したがって、ユーザは、検索段階に応じてこれら３つの処理のいずれかを選択して入力操作する。

【００５７】そして、文書データベース３ｂへの登録処理が指示されたときはステップＳ４に進んで文書登録処理を実行し、ユーザプロファイル３ｃの更新処理が指示されたときはステップＳ５に進んでプロファイル更新処理を実行し、検索実行処理が指示されたときはステップＳ６に進んで検索実行処理を実行し、その後ステップＳ７に進んで上記の各処理の処理結果を表示パターンに展開して出力し、ステップＳ２に戻る。

【００５８】図９はステップＳ４（図８）で実行される文書登録処理の処理手順を示すフローチャートであって、後述する検索処理を実行するために文書ベクトルを文書データベース３ｂに登録する。

【００５９】ステップＳ１１では入力されたクエリから形態素解析を行って単語の抽出処理をし、次いで係り受け解析を行う。そして続くステップＳ１１では係り受け解析により解析された係り単語及び受け単語と共起データベース３ｄとを照合し、当該係り単語及び受け単語を組にした文字列が共起データベース３ｄに格納されている場合は単語の語義を特定する。

【００６０】尚、語義が特定できなかった単語についてはその表記を有する全ての語義の単語ベクトルに頻度別の重みをつけて加算される。

【００６１】次に、ステップＳ１３では文書ベクトルの生成処理を行う。すなわちステップＳ１１とステップＳ１２で抽出された単語及び特定された語義から単語ベクトル辞書３ａを検索して意味ベクトルの特徴量を算出し、その総和から文書を特徴付ける文書ベクトルの特徴量を生成する。すなわち、文書ベクトルは、上述したように文書の表現する意味を表すものであり、各単語に関し単語ベクトル辞書３ａに書き込まれた意味ベクトルの特徴量を加算していくことにより生成される。

【００６２】そして続くステップＳ１４では文書データベース３ｂへの登録処理を行い、メインルーチン（図８）に戻る。すなわち、文書の内容とステップＳ１３で得られた文書ベクトルの特徴量を文書データベース３ｂに登録すると共に該文書データベース３ｂのインデックスを更新する。

【００６３】図１０はステップＳ５（図８）で実行されるプロファイル更新処理の処理手順を示すフローチャートであって、ユーザからの指示により特定のドキュメントファイルにアクセスするとき、例えば、文書データベース３ｂに登録されていない個人使用のＦＤ等の外部記憶媒体へのファイルの読み書き、或いはインタネットを介したＷｅｂページにアクセスするとき等に実行される。

【００６４】ステップＳ２１では文書データを入手し、次いで、ステップＳ２２で形態素解析により単語を抽出した後、係り受け解析を行う。次いで、ステップＳ２３では、上述と同様、共起データベース３ｃを参照し、係り単語と受け単語の組が共起データベース３ｃに格納されている場合は単語の語義を特定する。

【００６５】次に、ステップＳ２４では、上述と同様、ステップＳ２１とステップＳ２２とで抽出された単語及び特定された語義から単語ベクトル辞書３ａを検索して意味ベクトルを生成し、その後文書ベクトルを生成する。ステップＳ２５では生成された文書ベクトルを累積プロファイルに加算し、続くステップＳ２６では「１」を基準にして累積プロファイルを正規化し、これにより正規化プロファイルを作成する。

【００６６】このようにしてユーザプロファイルを更新した後、ステップＳ２７では本来の処理である各ファイルの処理（例えば、ファイルの参照処理、書き込み処理など）を行い、その後メインルーチンに戻る。

【００６７】図１１はステップＳ６（図８）で実行される検索実行処理の処理手順のフローチャートである。

【００６８】ステップＳ３１は検索クエリ入力処理を実

行し、ユーザは自然文や複数のキーワード或いは既存の文書指定等によりクエリを入力し、入力内容に応じたクエリのテキストストリングを入手する。例えば、クエリとして既存の文書を指定した場合は該文書にアクセスし、適当なフォーマットに変更して当該文書の内容をテキストファイル化し、そのテキストストリングを入手する。

【００６９】次いで、ステップＳ３２では前記テキストストリングに基づいてクエリベクトルの生成処理を行う。

【００７０】図１２はステップＳ３２で実行されるクエリベクトル生成処理ルーチンのフローチャートである。

【００７１】すなわち、ステップＳ４１ではユーザ指定の検索クエリから単語を抽出し、形態素解析用辞書を使用して形態素解析を行い、更に係り受け解析を行う。続くステップＳ４２では全ての係り受け解析の結果と共起データベース３ｄとを照合し、解析された係り単語と受け単語との組が共起データベース３ｄに格納されている場合は単語の語義を特定する。

【００７２】次に、ステップＳ４３ではクエリ中の全ての単語の多義性が解消されたか否かを判断し、解消されている場合は直ちにステップＳ４５に進む一方、解消されていない場合はステップＳ４４に進んでユーザプロファイルに基づく多義解消を行い、その後、ステップＳ４５に進む。

【００７３】具体的には、ステップＳ４４では多義解消されなかったクエリ中に表記された単語の全ての語義を示す単語ベクトルＸと、正規化ユーザプロファイルベクトルＱとの余弦測度ＳＤ（Ｘ，Ｑ）を求め、該余弦測度ＳＤ（Ｘ，Ｑ）を類似度として算出する。すなわち、単語ベクトルＸは、選択される語義が１つだけの場合もあり、また複数存在する場合もあり、一般的には数式（１）示すようにｎ次元（ｘ１～ｘｎ）のベクトルで表される。同様に正規化ユーザプロファイルベクトルＱも数式（２）に示すようにｎ次元（ｑ１～ｑｎ）のベクトルで表され、また、余弦測度ＳＤ（Ｘ，Ｑ）は両ベクトルの内積を両ベクトルの絶対値の積で除算した値となる。しかるに単語ベクトルＸ及び正規化ユーザプロファイルベクトルＱは「１」を基準に正規化されているため、余弦測度ＳＤ（Ｘ，Ｑ）は前記内積に相当し、したがって、余弦測度ＳＤ（Ｘ，Ｑ）は、数式（３）に示すように、両ベクトルの同次元の特徴量の積の総和となる。

【００７４】

【数１】

$$\vec{X} = (x1, x2, x3, \cdots, xn) \quad \cdots(1)$$

$$\vec{Q} = (q1, q2, q3, \cdots, qn) \quad \cdots(2)$$

$$SD(X, Q) = \cos\theta$$

$$= (\vec{X} \cdot \vec{Q}) / (|X| \cdot |Q|)$$

$$= \vec{X} \cdot \vec{Q}$$

$$= \sum_{k=1}^{n} (xk \cdot qk) \quad \cdots(3)$$

【００７５】このようにして余弦測度ＳＤ（Ｘ，Ｑ）、すなわち類似度を求め、ある閾値以上に類似する語義を選択して無関係と解される語義を除外することにより、ユーザプロファイルによる多義解消を行う。

【００７６】このように、ステップＳ４２で共起データベースにより多義解消できなかった単語に対してユーザプロファイルによる多義解消を行う。ここで強調すべき点は、ユーザプロファイルによる多義解消に優先して共起情報による多義解消が行われることである。

【００７７】そして、ステップＳ４５では、クエリ拡張辞書３ｅを使用してクエリの拡張を行う。すなわち、ユーザの指示に従い、「類義語展開のみ」、「類義語展開＋関連語展開」、「関連語展開のみ」などのバリエーション処理を行う。

【００７８】次に、ステップＳ４６では検索クエリの文書ベクトル生成処理を行う。すなわち、これまでの処理で抽出された単語及び特定された語義から単語ベクトル辞書３ａを検索し、単語ごとの次元別の特徴量を算出し、その総和から文書ベクトルを生成して図１１のルーチンに戻る。

【００７９】次に、図１１のステップＳ３３ではステップＳ３２で得られたクエリベクトルとＱ′と検索対象となる文書データベース３ｂの文書ベクトルＸ′とから余弦測度ＳＤ（Ｘ′，Ｑ′）、すなわち類似度を算出し、ＲＡＭ７に格納する。

【００８０】図１３はステップＳ３３で実行される類似度生成処理ルーチンのフローチャートである。

【００８１】すなわち、ステップＳ５１では文書データベース３ｂ内の検索対象となる文書を指定するカウンタのカウント値Ｎを初期値１にセットし、続くステップＳ５２では文書データベース３ｂを検索し、Ｎ番目（最初のループではＮ＝１）の文書の文書ベクトルＸ′を読み出し、ステップＳ５３ではＮ番目の文書ベクトルＸ′と検索クエリのクエリベクトルＱ′とに基づいて類似度を算出する。すなわち、ステップＳ５３では検索クエリを１つの文書とみなしてクエリベクトルＱ′を求め、検索対象の文書データベース３ｂ上の文書の文書ベクトルＸ′とクエリベクトルＱ′との余弦測度ＳＤ（Ｘ′，Ｑ′）を求め、類似度を算出する（下記数式（４）～（６）参照）。

【００８２】

【数２】

$$\vec{X'} = (x'1, x'2, x'3, \cdots, x'n) \quad \cdots(4)$$

$$\vec{Q'} = (q'1, q'2, q'3, \cdots, q'n) \quad \cdots(5)$$

$$SD(X', Q') = \cos\theta'$$

$$= (\vec{X'} \cdot \vec{Q'}) / (|X'| \cdot |Q'|)$$

$$= \vec{X'} \cdot \vec{Q'}$$

$$= \sum_{k=1}^{n} (x'k \cdot q'k) \quad \cdots(6)$$

【００８３】そして、例えば、「フォーム」という表記を上記図５（ａ）（ｂ）の２つのプロファイルに従って解釈した場合、図５（ａ）のプロファイルに従うと、次元７の特徴量が大きいので、図３の単語７と単語８とでは、次元７の特徴量が大きい単語８（「フォーム(姿勢)」）との内積が大きくなり、「姿勢」の語義が採用される。

【００８４】一方、図５（ｂ）のプロファイルの従うと、次元４の特徴量が大きいので、図３の単語７と単語８とでは、次元４の特徴量が大きい単語７「フォーム(帳票)」との内積が大きくなり、「帳票」の語義が採用される。

【００８５】次に、ステップＳ５４では算出された類似度をＲＡＭ７に格納し、続くステップＳ５５では文書データベース３ｂ内の検索対象文書に残文書があるか否かを判断し、存在しない場合はそのまま図１１のルーチンに戻る一方、存在する場合はステップＳ５６でカウンタのカウント値Ｎを「１」だけインクリメントしてステップＳ５２に戻り、上述の処理を繰り返す。

【００８６】尚、本実施の形態では前記類似度をＲＡＭ７に格納しているが、文書データベース３ｂに登録してもよい。

【００８７】次に、図１１のルーチンに戻り、ステップＳ３４ではＲＡＭ７を参照し、ステップＳ３３で得られた文書ごとの類似度を順序付けする。そして、ステップＳ３５ではステップＳ３４で順序付けされた文書を検索結果としてリストアップし、表示装置２に表示する。尚、この時、ステップＳ３３で登録された類似度の値も同時に表示する。

【００８８】このように本実施の形態によれば、共起データベース３ｄに従ってクエリを解析することにより、クエリの語義を正確に解釈することができ、これによりクエリの多義性解消を高精度に行なうことができ、また、共起データベース３ｄに基づいた多義解消を行なうことができない場合は、ユーザプロファイル情報によって、ユーザの過去の嗜好に従って多義解消することができるので、よりユーザの意図に即した検索精度の高い検索結果を容易且つ迅速に得ることができる。

【００８９】図１４は本発明に係る情報検索装置としての文書検索装置の第２の実施の形態を示すブロック構成図であって、本第２の実施の形態ではクエリの拡張を行わない場合を示しており、クエリ拡張辞書が省略されている。

【００９０】図１５は本第２の実施の形態におけるクエリベクトル生成処理ルーチンのフローチャートであって、ステップＳ６１ではユーザ指定の検索クエリから単語を抽出し、形態素解析用辞書を使用して形態素解析を行い、更に係り受け解析を行う。続くステップＳ６２では全ての係り受け解析の結果と共起データベース３ｄとを対照し、解析された係り単語と受け単語との組が共起データベース３ｄに格納されているかどうかに応じて各語義のもっともらしさ（語義尤度）を算出していく。

【００９１】次に、ステップＳ６３では上記第１の実施の形態と同様、余弦測度に基づく類似度を算出し、類似度に従って語義尤度を求めていく。そしてステップＳ６２、Ｓ６３で求めた語義尤度を合算し、最終的に最ももっともらしいとされた語義を選択する。このとき、語義尤度の重みとしてＳ６２の語義尤度に対する重みをより大きくすることで、共起情報による多義解消をプロファイルによる多義解消よりも優先する。

【００９２】そして、ステップＳ６４では、検索クエリの文書ベクトル生成処理を行う。すなわち、これまでの処理で抽出された単語及び特定された語義から単語ベクトル辞書３ａを検索し、単語ごとの次元別の特徴量を算出し、その総和から文書ベクトルを生成している。

【００９３】このように本実施の形態は、クエリ拡張を行わない場合の例を示すと共に、共起データベースに基づく多義解消を、ユーザプロファイル情報による多義解消よりも優先する別の実施形態を示している。

【００９４】尚、本発明は上記実施の形態に限定されるのではない。

【００９５】上記実施の形態では、文書検索方式として類似文書検索について説明したが、他の検索方式に適用することもできる。例えば、従来の全文検索システムにおいてもクエリを類義語展開することがあるが、本発明によればクエリが語義ベースで解析されているので、図７に示すような語義ベースの類義語辞書により容易に必要な類義語だけを展開することができ、また展開単語は特定語義についての類義語に限定されるので、検索ノイズを減少させることができる。

【００９６】また、上記実施の形態では、ユーザプロファイルの更新をファイルアクセス毎に更新するように構成したが、アクセスしたファイルの履歴情報のみを記録しておき、ある所定期間ごとに一括してプロファイルを更新するように構成するようにするのも好ましい。この場合はファイルアクセス毎に余分な処理時間を要することなく快適にファイルアクセスすることができ、また、通常コンピュータを使用しない深夜などに一括してプロファイルを更新することもでき、この場合はプロファイル更新による通常ユーザ層に対する処理時間的影響はより軽微となる。

【００９７】また、ユーザプロファイルをアクセスした

ファイル履歴から構成するようにしているが、ユーザが直接このユーザプロファイルを作成するようにしてもよい。

【００９８】また、ユーザが直接ユーザプロファイル情報を最初から作成するのは困難な場合があるため、ある種のガイドラインを作成し、システムの質問に応えていくだけでプロファイルが作成されるようにしてもよい。

【００９９】さらに、上記実施の形態では、ユーザプロファイルは各個人が別々の情報を保有するように構成したが、会社組織などにおいては各グループ単位でプロファイルを保有することも考えられ、斯かる場合はグループ内の他のメンバーによるファイルアクセスによってプロファイル情報が更新されることとなる。

【０１００】上述の実施形態においては、語義の多義性を解消する方法として、共起データベースによる方法、ユーザプロファイルによる方法の２種類を挙げたが、多義解消手段はこの２種類に限定されるものではない。例えば、各単語の語義リストを表示し、該語義リストの中から所望の語義をユーザが選択するようにしてもよく、文脈に応じて語義を解釈するようにしてもよい。すなわち、ユーザの発行する数多くのクエリに対して、文脈ベクトルを用意し、クエリ入力ごとに文脈ベクトルを更新することにより、新たなクエリ入力では重要単語を省略してもユーザの意図通りの検索を行なうことが可能となり、斯かる多義解消方法を混在するようにしてもよい。

【０１０１】

【発明の効果】以上詳述したように本発明によれば、ベクトル空間モデルを応用した類似文書検索において共起情報に従って検索クエリを解析し多義解消するので、クエリが正確に解釈でき、ユーザの意図に沿った検索精度の高い情報検索を行なうことができる。

【０１０２】また、検索クエリ中の多義語をユーザの過去の嗜好を表現するユーザプロファイル情報を参照して多義解消するので、クエリをよりユーザの嗜好に合わせて解釈でき、ユーザの意図に沿った検索精度の高い情報検索を行うことができる。また、共起情報による多義解消をユーザプロファイル情報による多義解消よりも優先するので、よりユーザの意図に沿った検索精度の高い情報検索を行なうことができる。

【図面の簡単な説明】

【図１】本発明に係る情報検索装置としての文書検索装置の一実施の形態（第１の実施の形態）を示すブロック構成図である。

【図２】表示装置の表示画面の一例を示す図である。

【図３】単語ベクトル辞書のフォーマット図である。

【図４】文書データベースのフォーマット図である。

【図５】ユーザプロファイルのフォーマット図である。

【図６】共起データベースのフォーマット図である。

【図７】クエリ拡張辞書ののフォーマット図である。

【図８】本発明に係る情報検索方法としての文書検索方法の検索手順を示すメインルーチンのフローチャートである

【図９】文書登録処理ルーチンのフローチャートである。

【図１０】プロファイル更新処理ルーチンのフローチャートである。

【図１１】検索実行処理ルーチンのフローチャートである。

【図１２】クエリベクトル生成処理ルーチンのフローチャートである。

【図１３】類似度生成処理ルーチンのフローチャートである。

【図１４】本発明に係る情報検索装置としての文書検索装置の第２の実施の形態を示すブロック構成図である。

【図１５】第２の実施の形態におけるクエリベクトル生成処理ルーチンのフローチャートである。

【符号の説明】

1　入力装置
3　HD
9　CPU

【図６】

3d

係り単語	助詞	受け単語
投球	null	フォーム（姿勢）
フォーム（帳票）	に	入力
登録	null	フォーム（帳票）

【図１】

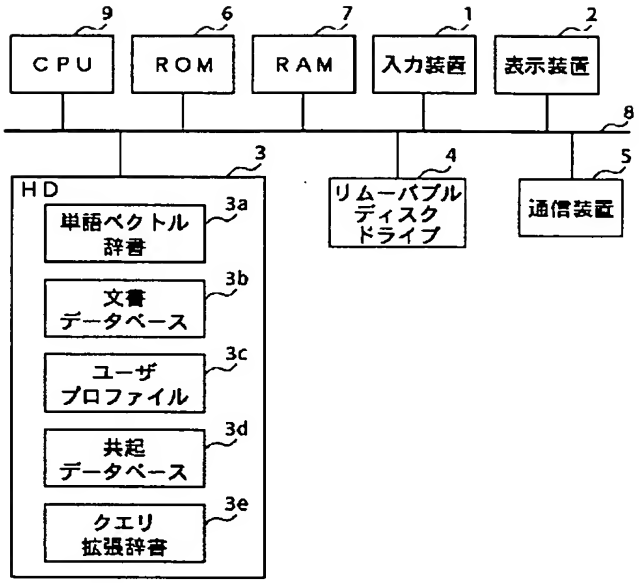

【図２】

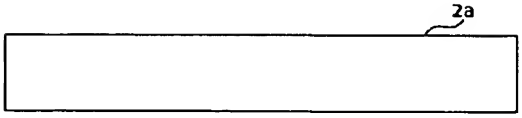

文書ＩＤ	文書タイトル	類似度
1028	タイトル1028	95
877	タイトル877	93
23988	タイトル23988	90
10029	タイトル1002	83
2897	タイトル2897	82
9999	タイトル9999	82
88	タイトル88	80
11987	タイトル11987	77
14576	タイトル14576	74
18726	タイトル18726	74
29837	タイトル29837	73
23874	タイトル23874	73
10098	タイトル10098	70
8729	タイトル8729	70
9872	タイトル9872	70
5456	タイトル5456	65

2b

【図３】

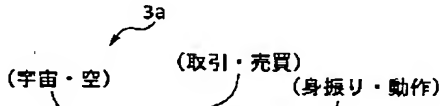

単語＼次元	1	2	3	4	5	6	7	8	9	10	……
1	0	23	32	0	0	10	0	0	0	3	……
2	34	0	0	0	2	0	22	21	0	0	……
3	4	22	0	4	0	0	0	0	9	0	……
4	3	12	32	4	0	7	0	0	32	0	……
5	0	0	0	0	0	0	0	14	0	0	……
6	4	0	6	8	0	0	0	0	0	0	……
7 (ﾌｫｰﾑ(帳票))	4	7	0	21	0	0	1	3	5	0	……
8 (ﾌｫｰﾑ(姿勢))	1	5	0	0	0	3	23	0	8	0	……
9	1	0	0	0	0	0	12	0	0	0	……
10	0	0	0	21	0	0	14	0	3	0	……
11	0	10	0	9	0	0	21	0	0	0	……
12	12	0	34	6	0	12	14	24	32	0	……
13	0	0	19	0	0	0	22	32	0	6	……
14	0	0	0	6	0	0	5	0	0	0	……
15	13	11	34	3	8	0	0	44	0	12	……
……											

【図７】

(a)

3e

見出語	類義語
フォーム（姿勢）	姿勢、形、スタイル、ポーズ
フォーム（帳票）	書式、伝票、帳票
椅子	腰掛け、チェア、ソファ、ベンチ
⋮	⋮

(b)

起点語	関連語
フォーム（姿勢）	スポーツ、分析、改善
フォーム（帳票）	購入、申し込み、振り込み、送金
⋮	⋮

【図４】

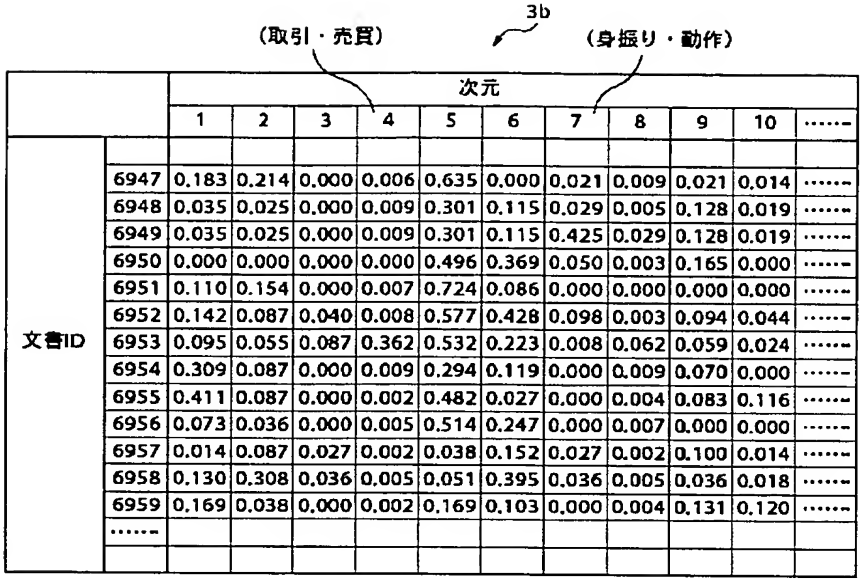

文書ID	次元 1	2	3	4	5	6	7	8	9	10	……
6947	0.183	0.214	0.000	0.006	0.635	0.000	0.021	0.009	0.021	0.014	……
6948	0.035	0.025	0.000	0.009	0.301	0.115	0.029	0.005	0.128	0.019	……
6949	0.035	0.025	0.000	0.009	0.301	0.115	0.425	0.029	0.128	0.019	……
6950	0.000	0.000	0.000	0.000	0.496	0.369	0.050	0.003	0.165	0.000	……
6951	0.110	0.154	0.000	0.007	0.724	0.086	0.000	0.000	0.000	0.000	……
6952	0.142	0.087	0.040	0.008	0.577	0.428	0.098	0.003	0.094	0.044	……
6953	0.095	0.055	0.087	0.362	0.532	0.223	0.008	0.062	0.059	0.024	……
6954	0.309	0.087	0.000	0.009	0.294	0.119	0.000	0.009	0.070	0.000	……
6955	0.411	0.087	0.000	0.002	0.482	0.027	0.000	0.004	0.083	0.116	……
6956	0.073	0.036	0.000	0.005	0.514	0.247	0.000	0.007	0.000	0.000	……
6957	0.014	0.087	0.027	0.002	0.038	0.152	0.027	0.002	0.100	0.014	……
6958	0.130	0.308	0.036	0.005	0.051	0.395	0.036	0.005	0.036	0.018	……
6959	0.169	0.038	0.000	0.002	0.169	0.103	0.000	0.004	0.131	0.120	……
……											

【図９】

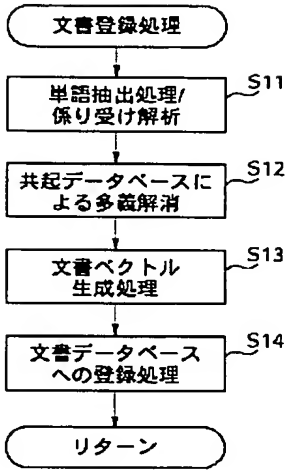

【図５】

(a)

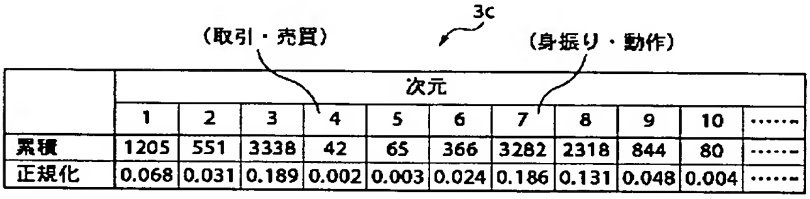

	次元 1	2	3	4	5	6	7	8	9	10	……
累積	1205	551	3338	42	65	366	3282	2318	844	80	……
正規化	0.068	0.031	0.189	0.002	0.003	0.024	0.186	0.131	0.048	0.004	……

(b)

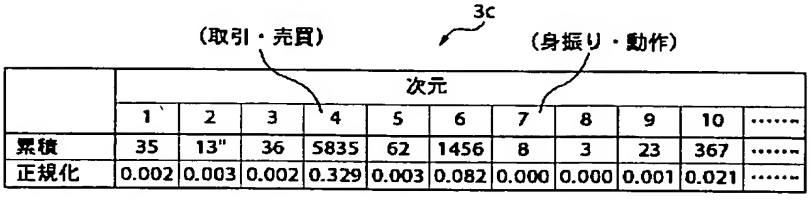

	次元 1	2	3	4	5	6	7	8	9	10	……
累積	35	13"	36	5835	62	1456	8	3	23	367	……
正規化	0.002	0.003	0.002	0.329	0.003	0.082	0.000	0.000	0.001	0.021	……

【図１０】

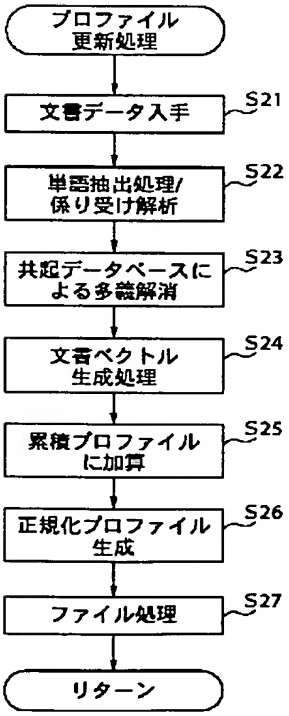

【図８】

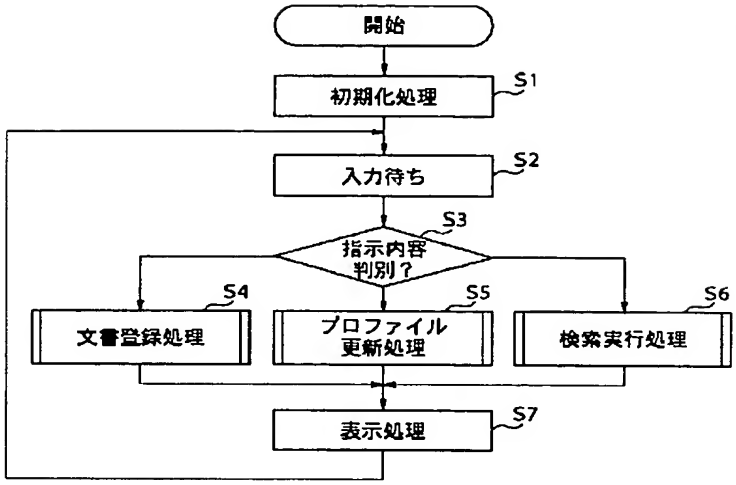

【図１１】

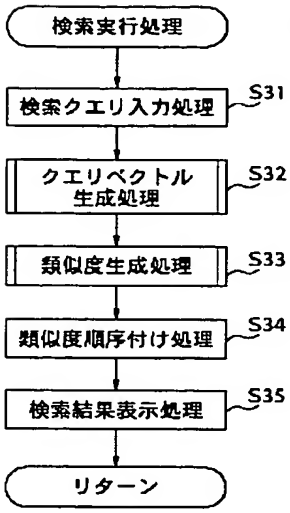

【図１５】

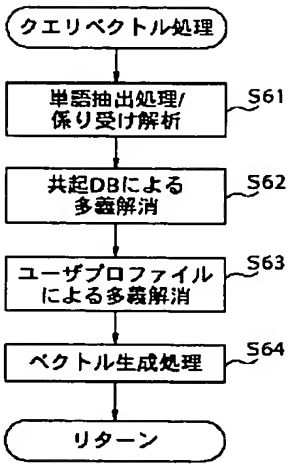

【図１２】

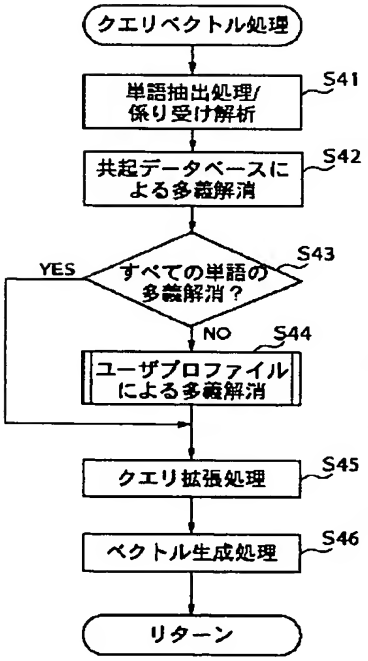

【図１３】

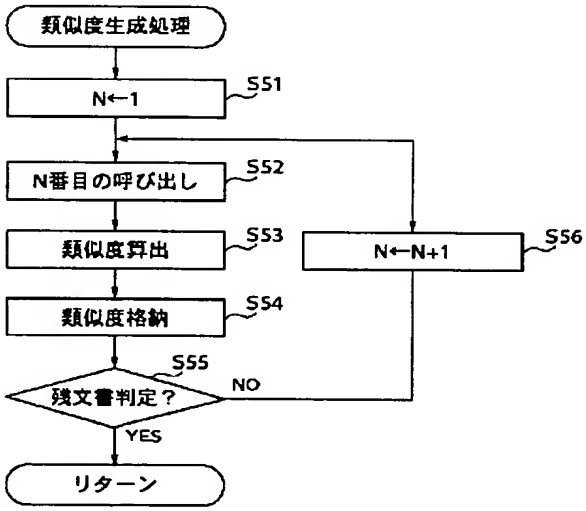

【図１４】

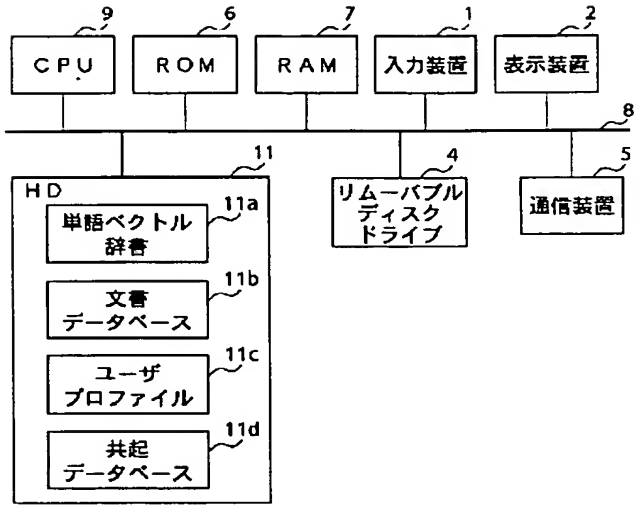
9
6
7
1
2
CPU
ROM
RAM
入力装置
表示装置
8
11
4
5
HD
単語ベクトル辞書
11a
リムーバブルディスクドライブ
通信装置
文書データベース
11b
ユーザプロファイル
11c
共起データベース
11d